

ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU
ŠUMARSKI ODSJEK

SVEUČILIŠNI DIPLOMSKI STUDIJ
DIPLOMSKI STUDIJ URBANOG ŠUMARSTVA, ZAŠTITE PRIRODE I OKOLIŠA

Antonio Božić

UPOTREBA LASERSKOG SKENERA (LIDAR) U
ISTRAŽIVANJU DINAMIKE BUKOVE PRAŠUME
MEDVJEDAK

DIPLOMSKI RAD

ZAGREB, 2016.

ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU
ŠUMARSKI ODSJEK

UPOTREBA LASERSKOG SKENERA (LIDAR) U ISTRAŽIVANJU
DINAMIKE BUKOVE PRAŠUME MEDVJEDAK

DIPLOMSKI RAD

Diplomski studij: Urbano šumarstvo, zaštita prirode i okoliša

Predmet: Prašume i šumski rezervati

Ispitno povjerenstvo:

1. Doc. dr. sc. Stjepan Mikac
2. Doc. dr.sc. Damir Ugarković
3. Dr. sc. Vinko Paulić

Student: Antonio Božić

JMBAG: 0068211807

Broj indeksa: 516/14

Datum odobrenja teme: 11.4.2016

Datum predaje rada: 23.9.2016

Datum obrane rada: 3.10.2016

Zagreb, rujan, 2016.

Dokumentacijska kartica

Naslov	Upotreba laserskog skenera (LiDAR) u istraživanju dinamike bukove prašume Medvjedak
Title	Using Light Detection and Ranging sensor (LIDAR) for the research of the dynamic beech old-growth forest Medvjedak
Autor	Antonio Božić
Adresa autora	Horvaćanska cesta 158, 10 000 Zagreb
Mjesto izrade	Šumarski fakultet Sveučilišta u Zagrebu
Vrsta objave	Diplomski rad
Mentor	Doc. dr. sc. Stjepan Mikac
Izradu rada pomogao	Izrada ovoga diplomskog rada potpomognuta je od strane Hrvatske zaklade za znanost (HRZZ) usklonu projekta IP-2014-09-1834 CroFEM
Godina objave	2016.
Obujam	Broj stranica: 28 tablica:4 , slika:11 , navoda literature: 60
Ključne riječi	LiDAR, prašuma, dinamika progala, geomorfološki faktori, šumski rezervat
Key words	LiDAR, old-growth forest, gaps dynamic, geomorphological factors, forest reserve
Sažetak	<p>Istraživanje progala u prašumama je važan izvor informacija o prirodnoj sindinamici koja služi kao predložak za prirodni blisko gospodarenje šumama. Međutim detaljnije analize progala izostaju zbog poteškoća u ocrtavanju granica progala i manjka isplativih metoda potrebnih za prikupljanje podataka na terenu. Cilj ovog rada je analizirati uporabu LiDAR-a u istraživanju dinamike prašumskih sastojina na razini progala sklopa te analizirati utjecaj geomorfoloških čimbenika na distribuciju i udio progala. Uporaba LiDAR-a pokazala se kao točan i efikasan način evidencije i izmjere progala unutar šumskog rezervata Medvjedak. Progale manje površine su zastupljene u većem broju što ukazuje na pojedinačno odumiranje stabala kao glavni mehanizam stvaranja progala u istraživanom području. Distribucija površina progala ukazuje da je najveći broj progala malih površina te da broj progala opada sa povećanjem površina. Utvrđen je povećani udio progala na sjeverozapadnim ekspozicijama u odnosu na sjeverne ekspozicije. Rezultati istraživanja ukazuju da je dosadašnji način gospodarenja prebornim bukovim šumama blizak prirodnom načinu koji se odvija u prašumama.</p>

Zahvaljujem se mentoru doc.dr.sc Stjepanu Mikcu na savjetima i pomoći pri izradi diplomskog rada

Zahvaljujem se svim profesorima i asistentima na bezrezervnom angažmanu prilikom stjecanja novih znanja i vještina

Zahvaljujem se svim kolegama, prijateljima, i obitelji, a posebno roditeljima Jeleni i Ivici koji su mi bili stalna podrška tijekom studiranja

Sadržaj

1. UVOD.....	1
2. PROBLEMATIKA.....	8
3. CILJEVI ISTRAŽIVANJA.....	9
4. MATERIJALI I METODE RADA.....	11
4.1. Područje istraživanja.....	11
4.2. Prikupljanje podataka.....	11
4.3. Analiza podataka.....	12
5. REZULTATI.....	15
5.1. Digitalni model terena.....	15
5.2. Utjecaj nagiba terena na distribuciju progala.....	17
5.3. Utjecaj ekspozicije terena na distribuciju progala.....	18
5.4. Utjecaj izloženosti vjetru na distribuciju i površinu progala.....	19
5.5. Utjecaj nadmorske visine na distribuciju progala.....	20
6. RASPRAVA.....	21
7. ZAKLJUČCI.....	23
POPIS LITERATURE.....	24

POPIS SLIKA

Slika 1. Terestrički laserski skener i lasersko skeniranje iz zraka

Slika 2. Prikaz LiDAR povratnih točaka

Slika 3. Normalizacija LiDAR podataka

Slika 4. Model visine krošanja

Slika 5. Prikaz reljefa terena prašumskog rezervata Medvjedak

Slika 6. Delineirane progale sklopa

Slika 7. Distribucija površina progala u rezervatu Medvjedak

Slika 8. Prostorni raspored progala prema nagibu

Slika 9. Distribucija površina progala prema ekspozicijama terena u rezervatu Medvjedak

Slika 10. Distribucija površina progala prema dominantnom smjeru vjetra

Slika 11. Distribucija površina progala prema nadmorskim visinama u rezervatu Medvjedak

POPIS TABLICA

Tablica 1. Osnovne deskriptivne karakteristike progala prema nagibu terena

Tablica 2. Osnovne deskriptivne karakteristike progala prema ekspoziciji terena

Tablica 3. Osnovne deskriptivne karakteristike progala prema izloženosti vjetru

Tablica 4. Osnovne deskriptivne karakteristike progala prema nadmorskim visinama

1. UVOD

Šumarska znanost već desetljećima istražuje složene procese i zakonitosti funkcioniranja prašumskih ekosustava. Tako je u prašumi Čorkova uvala sustavna šumarska znanstvena istraživanja 1957. godine započeo akademik Milan Anić (Prpić 1972). U Europi su takvi procesi posebice istraženi u bukovo-jelovim, bukovim i smrekovim prašumama te šumskim rezervatima. Brojni autori su pokušali definirati prašumu na način da unutar definicije objedine ekološku i socijalnu komponentu. Prema Prpiću i Seletkoviću (2001), prašuma je prirodna šuma koja se oduvijek razvijala bez neposrednoga antropogenog utjecaja, dakle isključivo pod utjecajem prirodnih čimbenika. Prema Korpelu (1989,1995) to je ekološki stabilna šuma, s čvrstim i dinamički uravnoteženim odnosima između klime, tla (staništa) i organizama (biocenoze), a istodobno očuvana od takvih čovjekovih utjecaja koji bi mogli izmijeniti zakonitosti životnih procesa i njezinu strukturu.

Europske prašume nalaze se uglavnom u nepristupačnim predjelima u zaštitnim šumama visokih planina. najviše očuvanih prašuma u Europi pripada zajednicama bukve, jele i smreke, koje se nalaze na području Dinarida, Alpa i Karpata. Za razliku od tropskih prašuma, karakterizira ih mali broj vrsta, naročito na sjeveru Europe pa tako npr. u Skandinaviji vrlo često samo jedna vrsta drveća gradi prašume.

Prema procjenama u Europi je oko 0,3 milijuna ha prašuma, što iznosi oko 0,4% od ukupne površine šuma u Europi. Većina ih pripada mješovitim bukovo-jelovim, bukovo-jelovo smrekovim i čistim bukovim šumama. Prema Parviainenu (2005) ukupni broj šumskih rezervata sa karakteristikama prašume ima oko 2500.

Progale sklopa (Eng. *Gaps*) su mjesta u prostoru prašumske sastojine nastala odumiranjem jednog ili nekoliko nadstojnih stabala (Whitmore 1989). U prašumskim ekosustavima progale su posljedica režima prirodnih poremećaja, koji pokreću dinamiku prašumskog ekosustava.

Prema Schleimannu i Bockheimu (2011) progale predstavljaju glavne pokretače dinamike prašumskog ekosustava. Površina progale značajno utječe na rast i razvoj pomlatka, biološku raznolikost, ciklus kruženja tvari, mikroklimatske i mikrobiološke uvjete u prašumskoj sastojini (Muscolo i dr. 2007). Površina progala kreće se od 10 do preko 5000 m² (Schliemann i Bockheim 2011).

Prema Wattu (1947) manje progale sklopa mogu nastati odumiranjem ili lomljenjem većih grana na stablima. Veće progale ($>1000 \text{ m}^2$) nastaju uglavnom djelovanjem požara i olujnih vjetrova većih površinskih razmjera. U ekološkim smislu ovako nastale progale značajno se razlikuju od uobičajenih manjih progala, jer su u njima uvelike izmijenjeni ekološki uvjeti. Velike progale usljed značajno smanjene transpiracije, zbog odumiranja velikog broja stabala, mogu sadržavati veliku količinu vlage (površinsko zamočvarivanje), što je rijetkost kod manjih progala. Također u velikim progalama rubna stabla nemaju značajan utjecaj na količinu i razdiobu sunčevog zračenja kao što imaju u manjim progalama. Ekološki uvjeti (svjetlo, temperatura, vlaga zraka) u velikim progalama odgovaraju otvorenim nešumskim površinama. Velike progale također imaju značajan utjecaj na dinamiku prašuma i uglavnom su manje frekventne pojave od manjih progala. Velike progale imaju značajnu ulogu u održavanju biološke raznolikosti čitavog ekosustava, jer u njima sukcesija obnova započinje uglavnom pionirskim vrstama drveća i prizemnog rašća.

Obzirom na način postanka progale mogu biti egzogene i endogene. Egzogene nastaju djelovanjem vanjskih (okolišnih) čimbenika: vjetar, snijeg, led, požar, grom, poplave, bujice, erozije, patogene gljive, insekti dok endogene nastaju fiziološkim odumiranjem starih stabala (Diaci i Bončina 1998). Egzogeni čimbenici uglavnom uzrokuju ekscresni nastanak progala, obično većih površina. Posljedica endogenih čimbenika su obično progale malih dimenzija, jer se fiziološko odumiranje rijetko dešava na većim površinama i u većim grupama stabala. U bukovo-jelovim prašumama endogene progale najčešće nisu velike, obično se radi o površinama projekcije krošnje jednoga ili nekoliko stabala, te se vrlo brzo zatvaraju bočnim srastanjem krošanja rubnih stabala, naročito bukve. Endogene progale upravo zbog toga nisu mjesta ekstenzivnije obnove prašumske sastojine. Također odumrla stabla, naročito jele i smreke mogu duži niz godina provesti u dubećem stanju a da se ispod njih nimalo ne promjene ekološke prilike.

Opisivanje trodimenzionalnih svojstava realnih objekata u našem okruženju i njihova pohrana u digitalnom obliku su postali stvarnost u mnogim područjima ljudske aktivnosti. Osim toga, stalni napredak računalne tehnike i njezina sve učestalija uporaba dovode do potražnje za sve većom količinom kvalitetnih i detaljnih podataka, osobito o prostoru ljudske aktivnosti i objektima koji ih okružuju. S obzirom na njihovu kompleksnost i izvanrednu raznolikost, prije svega u geometrijskom smislu, za kvalitetno je opisivanje potrebna izuzetno velika količina mjerenih podataka. Toliku količinu podataka ne bi bilo moguće prikupiti dovođenjem mjerne

naprave u fizički kontakt s objektom za svaku mjerenu točku. Stoga se već čitavo stoljeće kao efikasan i kvalitetan način izmjere bez neposrednog kontakta s objektom koristi fotogrametrija. Osim fotogrametrije posljednjih se godina afirmirala i tehnologija prostornog laserskog skeniranja kao potpuno automatizirana i izuzetno efikasna metoda prikupljanja podataka (Gajski 2007)

Ova tehnologija, koja se uobičajeno označava skraćenicom LIDAR (*Light Detection and Ranging*) ima široku primjenu u različitim područjima kao npr.: geodezija, geologija, ekologija, arheologija, šumarstvo itd.

Pojam LIDAR se odnosi na optički mjerni instrument koji odašilje laserske zrake koje se odbijaju od vrlo sitnih čestica raspršenih u Zemljinoj atmosferi i potom registriraju u optičkom prijamniku. Drugi naziv za lidar je optički radar ili laserski radar.

LIDAR koji je uobičajeno poznat pod nazivom LADAR ili laserska altimetrija, je akronim za svjetlosno detektiranje u određenom vremenskom rasponu. To se odnosi na daljinsko očitavanje tehnologije koja emitira intenzivane, fokusirane zrake svjetlosti i mjeri vrijeme potrebno da refleksije budu detektirane senzorom . (Jamie Carter i dr. NOAA 2012)

Ti se podaci koriste za izračun raspona, ili udaljenosti, prema željenim objektima.

Na ovaj način Lidar je analogan radaru, osim što se bazira na impulsima laserske svjetlosti.

Trodimenzionalne koordinate (primjerice x,y,z, ili zemljopisna širina, duljina i visina) željenih objekata su izračunate iz

- 1) Vremenske razlike između emitiranog i povratnog laserskog impulsa
- 2) Kuta pod kojim se impuls otpušta
- 3) Apsolutnog položaja senzora na površini ili iznad površine Zemlje

Ova beskontaktna metoda je slična radaru, ali koristi laserske svjetlosne impulse umjesto radio valova. (Jamie Carter i dr., NOAA 2012)

Umjesto radio valova, Lidar koristi mnogo kraće valne duljine elektromagnetskog spektra obično u ultraljubičastom, vidljivom, ili bliskoinfracrvenom rasponu.

Ova tehnologija omogućuje direktnu izmjeru trodimenzionalnih struktura i terena na kojem se nalaze strukture. Ovisno o metodologiji koju koristimo za prikupljanje podataka, dobiveni podaci mogu biti veoma gusti, na primjer, 5 točaka po metru.

Takva visoka rezolucija daje veću preciznost pri izmjeri visina terena i područja iznad terena.

Sposobnost za snimanje visina u tako visokoj rezoluciji je glavna prednost LIDAR-a u odnosu na konvencionalne optičke instrumente, kao što su digitalni fotoaparati, za kreiranje modela terena. (Sumerling i dr., 2010)

Općenito se može reći da je LIDAR potpuno automatiziran, aktivan, optičko-mehanički postupak prikupljanja prostornih podataka dostupnih s aktualnih snimališta (Gajski 2007)

LIDAR tehnologija nije nova, razvijala se posljednjih 40 godina, i u početku se koristila za mapiranje čestica u atmosferi. (Carter i dr., NOAA 2012) Zbog sposobnosti dobivanja visoke rezolucije najviše se koristila u istraživanjima atmosfere i meteorologiji.

Razvoj ovih sustava tekao je veoma sporo, prije svega zbog njihove visoke cijene, pa su počeci razvoja vezani uz američku vojsku i njoj bliske istraživačke ustanove. Međutim, u posljednjih desetak godina ovu tehnologiju preuzimaju privatne tvrtke i počinju sa serijskom proizvodnjom, tako da danas na tržištu imamo veliki broj zračnih laserskih sustava: Leica, Optech, Riegl, Fugro, Toposys i dr.(Kujundžić 2007.). Tek se razvitkom globalnog pozicijskog sustava (GPS) 1980-ih, omogućilo precizno pozicioniranje različitih zrakoplovnih naprava koje su bile u mogućnosti izvršavati laserska skeniranja iz zraka. Od tada su razvijeni mnogi instrumenti za zrakoplovnu i satelitsku uporabu.

Osnovna izmjera napravljena LIDAR instrumentom je udaljenost između senzora i ciljane površine. Izmjera se dobije određivanjem vremenskog intervala koje prođe između emitiranja laserskog impulsa na površinu i refleksije tog impulsa natrag prema prijemniku senzora. Množenjem ovog vremenskog intervala s brzinom svjetlosti

Udaljenost = (Brzina svjetlosti x izmjereno vrijeme leta laserskog pulsa) / 2

$$d = \frac{c \times t_2}{2}$$

Zbog najbolje dostupnosti većih površina terena skeniranju i mogućnosti velike pokretljivosti skenera, najčešće se skeniranje vrši korištenjem aviona kao platforme koja nosi skener. Ograničena područja, osobito strmih površina terena, izrada detaljnih modela zgrada i pojedinačnih skulptura i ostalih predmeta, pogodniji su za skeniranje s nepomičnih snimališta.


Zbog toga se i tehnologija prostornog laserskog skeniranja dijeli na:

- lasersko skeniranje sa zemlje (eng. *Terrestrial Laser Scanning* - TLS)
- lasersko skeniranje iz zraka (eng. *Airborne Laser Scanning* - ALS)

Iako je osnovni princip određivanja koordinata mjerenih točaka (polarno određivanje) isti, tehnologije se bitno razlikuju. (Gajski 2007)

Lasersko skeniranje sa zemlje se temelji na tahimetriji, odnosno mjerenju horizontalnog i vertikalnog kuta te udaljenosti do pojedine točke prostora. Rezultat skeniranja je skup trodimenzionalnih koordinata (x,y,z) točaka koji se naziva oblak točaka.

Prostorna udaljenost između susjednih snimljenih točaka unutar oblaka točaka ovisi o blizini objekta snimanja i tehničkoj specifikaciji samog instrumenta. Većina današnjih skenera može snimiti vrlo guste oblake točaka, pa je tako moguće dobiti točke na snimljenom objektu međusobno udaljene tek jedan milimetar (Matijević i Roić 2002).



Slika 1. Terestrički laserski skener lijevo, i lasersko skeniranje iz zraka desno (Preuzeto iz *STUDIJA 3D*)

U šumarstvu, LiDAR se može koristiti za mjerenje trodimenzionalnih struktura šumskih sastojina i za kreiranje modela terena ispod sastojina. Šumska struktura obično generira prvi

povratni impuls od najgornjih granica krošnja, zatim slijedi manje intenzivni povratni impuls koji prolazi kroz krošnju, do šumskog terena. Povratni impulsi su klasificirani u dvije klase, terenski i iznad terenski. Terenski povratni impulsi mogu stvoriti detaljnu terensku mapu od područja interesa kojeg želimo, dok se povratni impulsi od krošnja mogu filtrirati kako bi pružili šumsku strukturu krošnja i srednju razinu šume. (Sumerling i dr. 2010)

Sposobnost da se simultano vizualizira teren i model krošnja sastojine pruža značajne prednosti za šumarsku struku. Tradicionalno, šumari su se morali pouzdati u topografske karte za terenske klasifikacije i terenske izmjere kako bi izračunali volumene stabala i visinske vrijednosti. Podaci LiDARA pružaju značajan napredak u odnosu na tradicionalne načine dobivanja podataka (Sumerling i dr. 2010). Sve veći broj organizacija vezanih na šumarstvo i šumarska struka upotrebljavaju LiDAR za izmjere inventure šuma.


Širok spektar informacija se može direktno dobiti od LiDARA uključujući digitalne modele reljefa, visine stabala, digitalni površinski modeli, pokrov krošnja, struktura šuma i profil krune krošnje, dok obrađeni podaci mogu otkriti geometrijske volumene krošnja, biomasu pokrova krošnja, indeks otvorenosti tabličnih visina kruna, broj delinacije kruna.

Širok spektar informacija se može direktno dobiti od LiDARA uključujući ponajprije procjene visine stabala (Nasset 1997a, 1997b, 2002, 2002b, Magnussen i Boudewyn 1998, Magnussen i dr. 1999, Nasset i Bjercknes 2001, Nasset i Okland 2002, Popescu i dr. 2002, Holmgren 2004, Nasset i Gobakken 2005, Goodwin i dr. 2006, Hollaus i dr. 2006, Maltamo i dr. 2006, Lee i Lucas 2007, Yu 2007), mogućnosti procjene broja stabala (Nasset i Bjercknes 2001), mogućnosti delinacije i izmjere dimenzija krošnja (Nasset i Okland 2002, Pouliot i dr. 2002, Popescu i dr. 2003, Andersen i dr. 2004, Goodwin i dr. 2006), mogućnosti procjene omjera smjese vrsta drveća (Donoghue i dr. 2007), mogućnosti procjene gustoće sastojina (Nasset 1997, 2001, 2002a, Nasset i Gobakken 2005, Lee i Lucas 2007), mogućnosti procjene temeljnice (Holmgren 2004), mogućnosti procjene volumena sastojina (Nasset 1997b, 2002a, Holmgren 2004, Maltamo i dr. 2006, Hollaus i dr. 2007), mogućnosti procjena biomase i zaliha ugljika u sastojinama (Nasset 2004, Popescu 2007, Zhao i dr. 2009, Garcia i dr. 2010), mogućnosti procjene rasta sastojina (Nasset i Gobakken 2005, Yu 2007, Woodget i dr. 2007) i dr.

Najveći problem metode je prorjeđivanje podataka, jer količina podataka nadilazi kapacitet uobičajene hardverske i softverske opreme (Basa i Juraj, 2011). Točnost izmjerenih podataka

je centimetarska i ovisi prvenstveno o GPS opremi, frekvenciji i visini letenja (Kujundžić, 2007).

Za aktivnosti inventure šuma, LiDAR se primarno upotrebljava za dobivanje bazičnih strukturalnih atributa stabala uključujući visinu, pokrov krošanja i vertikalnih profila. Ovi podaci mogu biti upotrebljeni kako bismo izvukli ostale prijeko potrebne izmjere uključujući temeljnicu i volumen drveta, kao i biomasa za alternativnu energiju i analiza sekvencijacije ugljika. (Sumerling i dr. 2010)



Slika 2. Prikaz LiDAR povratnih točkaka od običnog bora (*Pinus sylvestris* L.) lijevo, od smreke (*Picea abies* L.) u sredini, vazdazelenih stabala i listopadnog stabla desno (Preuzeto od Naesset)

2. PROBLEMATIKA

Prašume i šumski rezervati pružaju velike i vrijedne mogućnosti proučavanja režima prirodnih poremećaja i prirodne šumske sindinamike, upravo iz razloga što su se prašume i šumski rezervati razvijali pod utjecajem prirodnih procesa sa malim utjecajem ili bez direktnog ljudskog utjecaja (Foster i dr., 1996). Postoji nekoliko dostupnih metoda za kvantificiranje prirodnih poremećaja u prašumskim sastojinama, kao što su direktna promatranja neposrednih uzoraka oštećenja (Woods 2004), proučavanje progala krošanja (Runkle, 1982) i dendrokronologija (Lorimer and Frelich, 1989).

U području Dinarida, za izučavanje prirodnih procesa poremećaja najviše se koriste određene karakteristike progala krošanja (npr. distribucije veličine progala, frakcije progala, modalitet izmjere smrtnosti progala). Ovisno kako su progale krošanja definirane, takva izučavanja, odnosno istraživanja mogu sadržavati informacije o razvitku progala kroz zadnjih manje više 50 godina, ekvivalentno vremenu koje je potrebno progalama da se zatvore putem lateralnog rasta susjednih krošanja, ili da drveće unutar progala dosegne visinu donjih dijelova krošanja postranih stabala (15-20m). Međutim, takvim istraživanjima će najčešće nedostajati informacije o vremenu potrebnom za formiranje progala bez dodatnih dendrokronoloških podataka. Nadalje, s obzirom na količinu vremena koje je potrebno za izvršavanje terenskih mjerenja karakteristika progala, izučavanja progala su najčešće limitirane na sastojinsku skalu (npr. 10s ha).

U novije vrijeme, tehnike daljinskih istraživanja se koriste za kvantificiranje uzoraka progala na puno većim prostornim skalama (npr. 100s–1000s ha), ali takvim tehnikama nedostaju informacije temeljene na terenskim izmjerama kao što su modeli izmjere smrtnosti progala. Konačno, dendroekološka istraživanja su možda najpronijljivija iz razloga što pružaju informacije o starosnoj strukturi i prijašnjim poremećajima s visokom vremenskom rezolucijom tijekom nekoliko stoljeća. Međutim, samo je nekoliko takvih istraživanja napravljeno u Dinarskom području zbog toga što je vađenje izvrtaka u prašumskim rezervatima uglavnom zabranjeno.

Lasersko skeniranje iz zraka se afirmiralo u posljednjih desetak godina kao potpuno automatizirana i izuzetno učinkovita metoda prikupljanja prostornih podataka (Gajski 2007)

S obzirom na veliku učestalost mjerenja i do 200 kHz, u kratkom je vremenu moguće detaljno izmjeriti oblik površine terena i objekata na njoj.

U svrhu dobivanja položajnih koordinata uz laser se koristi i inercijalni sustav (engl. *Inertial*

Navigation System) te GNSS (najčešće GPS) senzor koji istovremeno određuje (opaža) i položaj.

Osnovna prednost prema standardnim fotogrametrijskim metodama leži u tome da je za izmjeru neke točke dovoljno prikupiti podatke samo jednog snimališta. Nije potreban uvid u istu točku i sa susjednog snimališta u nizu, kao što je to slučaj kod aerofotogrametrije. Na taj način je moguće posebno kvalitetno izmjeriti plohu terena u šumovitim područjima i gradovima. Rezultat skeniranja je kao i kod terestričkih laserskih skenera oblak točaka.

Sama izrada 3D modela (DMP-a) iz oblaka točaka zahtijeva daljnju obradu kroz interpolaciju karakterističnih točaka objekata pri čemu je važan čimbenik gustoća mjerenih točaka po objektu. Prostorna rezolucija (gustoća) prikupljenih podataka LiDAR-om obično se kreće od 1 do 10 točaka po m². (Cetl i dr., 2013)

Ono po čemu LiDAR predstavlja budućnost i posebnost u prikupljanju prostornih podataka je velika gustoća podataka, njihova točnost i brzina prikupljanja. Rezultat laserskog skeniranja predstavlja virtualnu mjerljivu stvarnost koja postaje ključni i nezaobilazni element u daljnjim istraživanjima i zadire u širok spektar znanstvenih disciplina. (Novak., 2007)

3. CILJEVI ISTRAŽIVANJA

Ciljevi ovog istraživanja su:

1. Ispitati mogućnost uporabe LiDAR-a za analize detekcije progala, njihove veličine i distribucije
2. Analizirati utjecaj geomorfologije terena na veličinu i distribuciju progala (nagib terena, nadmorske visina, ekspozicija terena te izloženosti vjetru - WEI eng. *Wind Exposure Index*)

4. MATERIJALI I METODA RADA

4.1 Područje istraživanja

Područje istraživanja obuhvaća šumski rezervat »Medvjedak« koji je smješten unutar većeg šumskog kompleksa bukovih šuma, u sjeveroistočnom dijelu Nacionalnog parka Plitvice. Zaštićen je i proglašen posebnim rezervatom šumske vegetacije 1976. godine. Prema važećem zakonu o zaštiti prirode je smješten u kategoriju zona stroge zaštite (1), podzona najstrože zaštite (1a) (NN 80/13). Obuhvaća tri odjela (26, 27 i 61). Ukupna površina rezervata iznosi 156,3 ha, te pripada sastojini brdske bukove šume sa mrtvom koprivom (*Lamio orvale-Fagetum sylvaticae* Horvat 1938), gdje je to dominantna šumska zajednica (Cestar i dr. 1982). U sloju drveća dominira bukva (*Fagus sylvatica* L.). Najniža točka rezervata je 580 m, a najviša 875 m nadmorske visine.

Geološka podloga je debelo uslojeni i masivni rudistni vapnenac, a zastupljena su tri tipa tla u određenom postotnom omjeru. Na uzvišenim položajima i na grebenima pojavljuje se crnica na vapnencima (10%), na strmim padinama smeđe tlo na vapnencu, plitko (20%), na blažim padinama smeđe tlo na vapnencu, srednje duboko (40%), te u vrtačama levisirano ili ilimerizirano tlo (30%). Srednja godišnja temperatura zraka iznosi 7,9° C, a srednja godišnja količina oborina 1510 mm (prema meteorološkoj stanici Plitvički Ljeskovac).

To je područje klimazonalne zajednice *Fagetum illiricum-montanum* (Pelcer i dr., 1982).


Prema Keppenovoj klasifikaciji ovdje prevladava tip klime Cfb. (umjereno topla i vlažna klima s toplim ljetima), klima bukve.

4.2 Prikupljanje podataka

Za svrhu izrade ovoga rada korišteni su laserski podaci dobiveni snimanjem Nacionalnog parka pomoću LiDAR-a u proljeće 2014. godine. Lidarsko snimanje obuhvaća niz pojedinačnih kvadrata površine 25 ha sa prosječnom gustoćom točaka od 25 kom/m² što u prosjeku iznosi oko 250 000 točaka/ha. Svaka pojedina točka sadrži tri prostorna atributa pomoću kojih je definiran njen trodimenzionalni položaj (x, y i z) u tzv. oblaku podatka (Eng. *Point clouds*)


4.3 Analiza podataka

Analiza podataka je obavljena pomoću programa LiFOREST 2.0 i to za čitavo područje rezervata Medveđak (oko 150 ha) uključujući i rubnu zonu (Žmegač 2015). Za svaki pojedini kvadrat napravljen je digitalni model terena u rezoluciji od 1 m te je provedena normalizacija točaka na način da je za svaku točku oduzeta visina dobivena sa modela terena.



Slika 3. Utjecaj nagiba na LiDAR podatke prije normalizacije (a) i nakon normalizacije (b) za obični bor (*Pinus sylvestris* L.) i planinski bor (*Pinus mugo* L.) na nagibu od približno 35° (Preuzeto od Khosravipour i sur.2015)

Na taj način je dobiven set točaka koji predstavlja normaliziranu visinu krova u našem slučaju prašume. Pomoću normaliziranih podataka je napravljen rasterski set podataka koji predstavlja model visine sklopa sastojine (nCHM - normalized Canopy Height Model) u prostornoj rezoluciji od 0,5 m.




Slika 4. Model visina krošanja (tamno - veće visine, svjetlo - manje visine)

Nakon toga u programu QGIS napravljena je klasifikacija modela visina sastojinskog sklopa (nCHM) na dvije kategorije (1 - sklop sastojine visina jednakih i većih od 15 m i 0 - progala sklopa visina manjih od 15 m). Tako dobivene klase su automatski vektorizirane i pretvorene u poligone. Za svaki poligon je izračunata površina i opseg, a progale manje od 10 m² su izostavljene iz analize. Za takve poligone se smatra da nisu progale sklopa jer su previše male i nemaju bitan ekološki efekt za analizu dinamike prašumske sastojine.

Iz digitalnog modela terena (rezolucije 1 m) izračunati su geomorfološki parametri: ekspozicija, nadmorska visina, nagib i izloženost vjetru. Za svaku progalu pojedinačno su izračunate srednje vrijednosti geomorfoloških parametara i napravljena je konačna baza podataka koja je poslužila za daljnje analize distribucije i površine progala obzirom na geomorfologiju terena (Žmegač 2015).

5. REZULTATI


5.1 Digitalni model terena



Slika 5. Prikaz reljefa terena prašumskog rezervata Medvjedak


Reljef je skupni naziv za sve oblike na Zemljinoj površini koji su nastali djelovanjem prirodnih sila. Taj termin ne obuhvaća sve elemente digitalnog modela reljefa, pa je zbog toga digitalni model reljefa neodgovarajući termin (Frančula i Lapaine 2008). Iz tog razloga, u praksi se češće koristi termin DMT odnosno digitalni model terena. DMT opisuje trodimenzionalni oblik Zemljine površine odnosno topografiju površine.

Model je numerički definiran nizom točaka s tri koordinate (X, Y i Z) u digitalnom obliku. (Cetl 2013.)



Slika 6. Delineirane progale sklopa (detalj)

Na slici 9. je prikazan jasno izlučeni prostorni raspored progala sklopa (površina većih od 10 m²) preklopljenih preko digitalnog modela terena . Iz slike je vidljivo da su progale sklopa izrazito nepravilnog i kompleksnog oblika te različitih površina.



Slika 7. Distribucija površina progala u rezervatu Čudinka

Distribucija površina progala ukazuje da je najveći broj progala malih površina te da broj progala opada sa povećanjem površina. Ukupni broj progala (površine > 10m²) iznosi 1245


kom. Preračunato po jednom hektaru to je 8,3 progala.

5.2 Utjecaj nagiba terena na distribuciju progala

Za analizu nagiba terena napravljena je klasifikacija progala prema nagibu u 4 klase. Rezultati prikazuju da je najveći broj progala utvrđen na nagibu od 10-30% (1004) , a najmanji broj je ispod 5% (17). Također srednja vrijednost progala najmanja je na nagibu manjem od 5-10% (7,87), a najveća na nagibu većem od 30% (49,43).

Tablica 1. Osnovne deskriptivne analize progala prema nagibu terena

Nagib	<5	5-10	10-30	>30
N	17	138	1004	86
Min	10	5	9	9
Max	199,5	9,97	879	362,25
Sum	744	1085,73	47132,5	4251,25
Mean	43,77	7,87	46,95	49,43
Std. error	12,0918	0,115973	2,081378	6,37883
Variance	2485,597	1,856048	4349,464	3499,295
Stand. dev	49,85577	1,362368	65,95047	59,15484
Median	23,25	8,07	24,5	25,1
25 prcentil	12,25	6,7675	14,3125	14,75
75 prcentil	54,25	8,9775	50,4375	60,25
Skewness	2,272771	-0,3397	4,741746	2,85854
Kurtosis	5,542958	-0,938213	35,73173	10,28759
Geom. mean	28,2028	7,742805	29,19031	31,27924
Coeff. var	113,9177	17,31617	140,4854	119,6664




Slika 8. Prostorni raspored progala prema nagibu

5.3 Utjecaj ekspozicije terena na distribuciju progala

Za analizu ekspozicije terena napravljena je klasifikacija progala prema ekspoziciji u 8 klasa. Analiza ukazuje da se najveći broj progala nalazi na jugozapadnoj ekspoziciji terena (496), a najmanji broj se nalazi na sjevernoj ekspoziciji terena (55). Također najveća prosječna površina progale je utvrđena na južnoj ekspoziciji (67,77 m²), a najmanja na sjevernoj (32,35m²)

Tablica 2. Deskriptivne karakteristike progala prema ekspoziciji terena

Ekspozicija	N	NE	E	SE	S	SW	W	NW
N	55	182	62	67	129	496	184	70
Min	9	9	9	9	9,25	9	9	10,5
Max	136,5	431,5	283,75	389,25	1718,5	879	312,25	452,75
Sum	1779,25	10427,75	3684,75	3788	8742,5	18809,25	7299,75	4084,5
Mean	32,35	57,30	59,43	56,54	67,78	37,92	39,68	58,35
Std. error	4,113466	5,261807	7,062715	10,35974	14,36738	2,634622	3,262718	9,006868
Variance	930,6333	5038,964	3092,681	7190,726	26628,38	3442,853	1958,74	5678,657
Stand. dev	30,50628	70,98566	55,61188	84,79815	163,1821	58,67583	44,25766	75,35686
Median	18,5	29,38	38,13	29,75	30	20,75	23,12	32,63
25 prentil	13	15,25	19,625	14	14,75	13	14,0625	19,25
75 prentil	42,5	67,75	86,6875	58,25	60,25	39,5625	45,625	65,6875
Skewness	1,894088	2,732276	1,831599	3,257052	8,4338	7,867138	3,239	3,286412
Kurtosis	3,04876	9,067312	4,034433	10,12564	83,17011	93,1118	14,07767	12,52585
Geom. mean	23,56408	34,41171	40,27791	32,60907	33,72187	25,00437	27,31727	37,15223
Coeff. var	94,30072	123,8943	93,57314	149,9862	240,7834	154,7282	111,5574	129,1463




Slika 9. Distribucija površina progala prema ekspozicijama terena u rezervatu Medvjedak

5.4 Utjecaj izloženosti vjetru na distribuciju i površinu progala

Parametar izloženosti vjetru se kreće u rasponu veći od 1 i manji od 1. Vrijednost veća od 1 predstavlja padine koje su izložene dominantnom smjeru vjetra. U ovoj analizi progale su podijeljene na dvije kategorije: >1 padine koje su izložene dominantnom vjetru i <1 padine koje nisu izložene dominantnom vjetru. Kruskal-Wallisov test je pokazao da nema značajne razlike između broja površine progala između ovih dviju kategorija.

Tablica 3. Deskriptivne karakteristike progala prema izloženosti vjetru

Vjetar	Area<1	Area>1
N	699	546
Min	9	9
Max	492	1718,5
Sum	34330	24285,75
Mean	49,11	44,48
Std. error	2,414556	4,01612
Variance	4075,228	8806,554
Stand. dev	63,83751	93,84324
Median	25,5	22,5
25 prcentil	14,5	13,75
75 prcentil	54,75	44,375
Skewness	3,328265	12,26694
Kurtosis	13,58604	198,1667
Geom. mean	30,39362	27,31984
Coeff. var	129,9808	210,9814




Slika 10. Distribucija površina progala prema dominantnom smjeru vjetra

5.5. Utjecaj nadmorske visine na distribuciju progala

Rezervat Medvjedak rasprostire se na nadmorskim visinama 570-869 m. Visine su podijeljene u 3 visinska stupca prema nadmorskoj visini (Tablica 4.). Rezultati Kruskal-Wallis testa ukazuju da ne postoje značajne razlike u površinama progala između visinskih stupaca. Najveći broj progala nalazi se na nadmorskoj visini od 570-700 m, dok se najmanji broj progala nalazi na nadmorskoj visini 800-869 m.

Tablica 4. Deskriptivne karakteristike progala prema nadmorskim visinama

Nadmorska visina	570-700	700-800	800-869
N	583	490	172
Min	9	9	9
Max	1718,5	431,5	492
Sum	28881	21174,75	8560
Mean	49,54	43,21	49,77
Std. error	3,906462	2,651731	5,135693
Variance	8896,84	3445,521	4536,559
Stand. dev	94,32306	58,69856	67,35398
Median	26	21,25	27
25 prcentil	14,25	13,75	15,375
75 prcentil	49,25	48	57
Skewness	11,23886	3,963774	3,909221
Kurtosis	178,922	19,23946	19,23721
Geom. mean	29,76771	27,44348	31,09936
Coeff. var	190,4032	135,833	135,3374



Slika 11. Distribucija površina progala prema nadmorskim visinama u rezervatu Medvjedak

6. RASPRAVA

Istraživanje progala u prašumama je važan izvor informacija o prirodnoj sindinamici koja služi kao predložak za prirodni blisko gospodarenje šumama. Međutim detaljnije analize progala izostaju zbog poteškoća u ocrtavanju granica progala i manjka isplativih metoda potrebnih za prikupljanje podataka na terenu.

Topografija visoke rezolucije dobivena iz LiDAR podataka jedan je od najboljih alata za proučavanje površina progala i granica progala.

Cilj ovog rada je bio analizirati uporabu LiDAR-a u istraživanju dinamike prašumskih sastojina na razini progala sklopa te analizirati utjecaj geomorfoloških čimbenika na distribuciju i udio progala. Upotrijebljeni LiDAR omogućuje znatno poboljšanu prostornu rezoluciju slike naspram starijih verzija, od 25 točaka/m² čime je mogućnost procjene karakteristika progala, njihova veličina, oblik, distribucija i broj znatno olakšana.

Uporaba LiDAR-a pokazala se kao točan i efikasan način evidencije i izmjere progala unutar šumskog rezervata Medvjedak. Iako upotreba LiDAR-a ne eliminira potrebu za terenskim radom, i za proučavanjem povijesnog konteksta proučavanoga područja, doista pomaže u detektiranju progaldjenih područja.

Progale manje površine su zastupljene u većem broju što ukazuje na pojedinačno odumiranje stabla kao glavni mehanizam stvaranja progala u istraživanom području. Također, smanjenjem površine povećava se kompleksnost progale što se dovodi u korelaciju s već spomenutim dominantnim čimbenikom nastanka progala odnosno sukcesivnim odumiranjem stabala u više navrata. Ovakve karakteristike progala potvrđene su u brojnim istraživanjima bukvo-jelovih srednjoeuropskih prašuma (Tabaku i Meyer 1999, Zeibig i dr. 2005, Roženberger i dr. 2007, Bottero i dr. 2011, Garbarino i dr. 2012). Prema navedenim istraživanjima najzastupljenije su progale površina projekcije jedne krošnje stabla dok su progale većih površina manje zastupljene. Takve površinske veće progale premda ih je manji broj imaju vrlo bitan utjecaj na biološku raznolikost prašumskih ekosustava. Poglavito jer omogućavaju preživljavanje heliofilnijih vrsta drveća kao što su: gorski javor, javor mlječ, gorski brijest i jasen.

Porastom nadmorske visine dolazi i do smanjenja postotnog udjela progala i njihove gustoće.

U padu je i prosječna površina progala na koju, uz porast nadmorske visine, svakako utječe i ekspozicija.

Utvrđen je povećani udio progala i njihova površina na jugozapadnim ekspozicijama u odnosu na sjeverne ekspozicije.

Smanjenje udjela progala i njihove prosječne površine sa porastom nadmorske visine možemo pripisati manjim obrastom stabala. Na većim nadmorskim visinama i izloženijim padinama stabla su nižih visina i manje gustoće što također može utjecati na postotni udio progala. Primjena rezultata ovih istraživanja ukazuje da je dosadašnji način gospodarenja prebornim bukovim šumama vrlo blizak prirodnom načinu koji se odvija u prašumama. I to naročito stablimična doznaka stabala uvažavajući standardne funkcije doznake: funkcija iskorištavanja, sanitarno higijenska funkcija, funkcija pomlađivanja i njege sastojina te funkcija održavanja preborne strukture.

Provedeno istraživanje također ukazuje na mogućnost u određenim situacijama i grupimične doznake u vidu progala većih površina koje će omogućiti preživljavanje brzorastućih heliofilnih vrsta drveća kao što su javori.

Buduća istraživanja svakako bi trebalo usmjeriti na povezivanje daljinskih i terestričkih metoda poglavito kod analiza odumiranja stabala i postanka progala, te pomlađivanja u njima.

7. ZAKLJUČCI

1. Uporaba LiDAR tehnologije precizno brzo i efikasno evidentiranje broja i veličine progala u bukovim prašumama, naročito na velikim površinama čime se znatno skraćuje terenski rad.
2. Razlike u visinama krošanja i karakteristikama progala su bile detektirane jedino kada su se proučavale detaljne strukture krošanja upotrebljavajući LiDAR tehnologiju.
3. Distribucija površina progala sklopa u rezervatu Medvjedak ima padajuću frekvenciju što ukazuje da su površinom manje progale zastupljenije od većih progala što djelomično upućuje da je dominantni čimbenik nastanka progala rezultat površinom manjih odumiranja stabala (pojedinačna odumiranja).
4. Postotni udio progala, njihova gustoća (kom/ha) i prosječna površina opada sa porastom nadmorske visine.
5. Analizom LiDAR snimaka zaključeno je da ekspozicija terena ima značajan utjecaj na površinu progala i to naročito u odnosu sjeverozapadnih i južnih ekspozicija.
6. Izloženost padina dominantnom vjetru ne pokazuje značajan utjecaj na veličinu i postotni udio progala. Ne postoje značajne razlike u padinama izloženijih vjetru s obzirom na relativnu progaljenost i na prosječne površine progala.
7. Dobiveni rezultati pokazuju da stablimična doznaka koja se provodi u gospodarskim bukovim šumama zapravo slijedi prirodni trend "sječe" koju priroda obavlja u prašumama. Stablimična doznaka se provodi i u dinarskim prašumama samo po bitno drugačijim kriterijima odabira od onih u gospodarskim šumama.

8. LITERATURA

- Andersen, H.E., R. McGaugheyb, S. Reutebuch , 2005: Estimating forest canopy fuel parameters using LiDAR data, *Remote Sensing of Environment* 94: 441-449.
- Basa, L., Juraj, I., 2011: Oblak točaka i AutoCAD Civil 3D 2011, *Ekscentar* 14, 34-39
- Bončina A, Diaci J (1998) Contemporary research on regeneration patterns of Central European virgin forests with recommendation for future research *ZbGL* 56:33-53
- Bottero, A., Garbarino, M., Dukić, V., Govedar, Z., Lingua, E., Nagel, T.A. i Motta, R. 2011. Gap-Phase Dynamics in the Old-Growth Forest of Lom, Bosnia and Herzegovina. *Silva Fennica*, 45(5), 875-887.
- Gajski D. (2007): Osnove laserskog skeniranja iz zraka, *Ekscentar*, no. 10, pp. 16-22.
- Carter J., Schmid K., Waters K., Betzhold L., Hadley B., Mataosky R., Halleran R., 2012: National Oceanic and Atmospheric Administration (NOAA) Coastal Services Center. "Lidar 101: An Introduction to Lidar Technology, Data, and Applications." Revised. Charleston: 3 str.
- Cestar D., V.Hren, Z. Kovačević, J. Martinović, Z. Pelcer, K. Bezak, A. Krznar, V. Lindić, B. Vrbek, V. Krejči, 1982: Prirodni šumski rezervat Medveđak. *Rad. Šumar. inst.* 50:1-76, Zagreb
- Cetl V., 2013: Primjena 3D modela u upravljanju gradom. *Studija*, Geodetski fakultet, Zagreb, 11-12: 14-15
- Donoghue, D., P. Watt , N. Cox , J. Wilson , 2007: Remote sensing of species mixtures in conifer plantations using LiDAR height and intensity data, *Remote Sensing of Environment* 110: 509–522.
- Foster, D.R., Orwig, D.A., McLachlan, J.S., 1996. Ecological and conservation insights from reconstructive studies of temperate old-growth forests. *Trends Ecol. Evol.* 11, 419–424.
- Frančula, N, Lapaine, M. (2008): Geodetsko geoinformatički rječnik. Republika Hrvatska, Državna geodetska uprava.

- Garcia, M., D. Riano , E. Chuvieco , F. MarkDanson, 2010: Estimating biomass carbon stocks for a mediterranean forest in central spain using LiDAR height and intensity data, *Remote Sensing of Environment* 114 (4): 816–830.
- Garbarino, Borgogno Mondino, Lingua, Thomas Nagel, Duki'c, et al.. Gap disturbances and regeneration patterns in a Bosnian old-growth forest: a multispectral remote sensing and ground-based approach. *Annals of Forest Science*, Springer Verlag/EDP Sciences, 2012, 69 (5), pp.617-625.
- Goodwin, N., N. Coops, D. Culvenor , 2006: Assessment of forest structure with airborne LiDAR and the effects of platform altitude, *Remote Sensing of Environment* 103: 140–152.
- Hollaus , M., W. Wagner , C. Eberhofer , W. Karel , 2006: Accuracy of large-scale canopy heights derived from LiDAR data under operational constraints in a complex alpine environment. *ISPRS Journal of Photogrammetry and Remote Sensing* 60: 323–338.
- Hollaus, H., W. Wagner , B. Maier , K. S chadauer , 2007: Airborne laser scanning of stem volume in a mountainous environment, *Sensors*, 7: 1559–1577.
- Holmgren, J., 2004: Prediction of tree height, basal area, and stem volume in forest stands using airborne laser scanning, *Scandinavian Journal of Forest Research*, 19 (6): 543–553.
- Korpel' Š.1989.Pralesy Slovenska.Veda, Bratislava, 329.pp.
- Korpel' Š.1995.Die Urwälder der Westkarpaten. G. Fischer-Verlag, Stuttgart, 310 pp.
- Khosravipour A., Andrew K. Skidmore, Tiejun Wang, Martin Isenburg, Kouros Khoshelham, Effect of slope on treetop detection using a LiDAR Canopy Height Model *ISPRS Journal of Photogrammetry and Remote Sensing* Volume 104, June 2015, Pages 44–52
- Kujundžić D. (2007): Zračni laserski skeneri LEICA ALS50-II i Corridor Mapper, *Ekscentar*, no. 10, pp. 31-34
- Lee, A., R.Lucas , 2007: A LiDAR-derived canopy density model for tree stem and crown mapping in Australian forests, *Remote Sensing of Environment* 111: 493–518.
- Lorimer, C.G., Frelich, L.E., 1989. A methodology for estimating canopy disturbance frequency and intensity in dense temperate forests. *Can. J. For. Res.* 19, 651–663.

- Magnussen, S., P. Boudewyn, 1998: Derivations of stand heights from airborne laser scanner data with canopy-based quantile estimators, *Canadian Journal of Forest Research*, 28: 1016–1031.
- Magnussen, S., P. Eggermont, V. N. La Riccia , 1999: Recovering tree heights from airborne laser scanner data, *Forest Science*, 45: 407–422.
- Maltamo, M., K. Eerikainen , P. Packalen , J. Hyypä, 2006: Estimation of stem volume using laser scanning-based canopy height metrics, *Forestry* 79 (2): 217–229.
- Matijević, H.; Roić, M (2002): Terestrički laserski skeneri, *Geodetski list*, 3, 171-187.
- Muscolo A, Sidari M, Mercurio R (2007). Influence of gap size on organic matter decomposition microbial biomass and nutrient cycle in Calabrian pine (*Pinus laricio* Poiret.) stands. *Forest Ecology and Management* 242: 412-418
- Nasset , E., 1997a: Determination of mean tree height of forest stands using airborne laser scanner data, *ISPRS Journal of Photogrammetry & Remote Sensing*, 52: 49–56.
- Nasset , E., 1997b: Estimating timber volume of forest stands using airborne laser scanner data, *Remote Sensing of Environment*, 61: 246–253.
- Nasset , E., 2002a: Predicting forest stand characteristics with airborne scanning laser using a practical two-stage procedure and field data, *Remote Sensing of Environment*, 80: 88–99.
- Nasset , E., 2002b: Determination of mean tree height of forest stands by means of digital photogrammetry, *Scandinavian Journal of Forest Research*, 17, 446–459.
- Nasset , E., 2004: Estimation of above- and belowground biomass in boreal forest ecosystems. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*. Vol. XXXVI (8/W2): 145–148, Freiburg.
- Nasset , E., K. O. Bjerknes , 2001: Estimating tree heights and number of stems in young forest stands using airborne laser scanner data, *Remote Sensing of Environment*, 78, 328–340.
- Nasset , E., T. Okland, 2002: Estimating treeheight and tree crown properties using airborne scanning laser in a boreal nature reserve, *Remote Sensing of Environment*, 79: 105 - 115.

- Nasset , E., T. Gobakken , 2005: Estimating forest growth using canopy metrics derived from airborne laser scanner data. *Remote Sensing of Environment*, 96 (3-4): 453-465
- Novak Z. (2007): Optech LiDAR, Ekscentar, no. 10, pp. 24-30.
- Parviainen, J., 2005. Virgin and natural forests in the temperate zone of Europe *For. Snow Landsc. Res.* 79, 1/2: 9–18 (2005) 9
- Pelcer , Z. & Lindić , V., 1982.: Vegetacija — Prirodni šumski rezervat Medvedjak. *Radovi* 50:7—13, Šumarski institut Jastrebarsko.
- Popescu , S., 2007: Estimating biomass of individual pine trees using airborne LiDAR. *Biomass and Bioenergy* 31: 646–655.
- Popescu , S., R. Wynne , R. Nelson , 2002: Estimating plot-level tree heights with LiDAR: local filtering with a canopy-height based variable window size, *Computers and Electronics in Agriculture* 31:71–95.
- Popescu , S., R. Wynne , R. Nelson , 2003: Measuring individual tree crown diameter with lidar and assessing its influence on estimating forest volume and biomass, *Canadian Journal of Remote Sensing*, 29 (5): 564–577.
- Pouliot , D. A., D. J. King, F. W. Bell , D. G. Pitt , 2002: Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration, *Remote Sensing of Environment*, 82:105–115.
- Prpić, B., 1972: Neke značajke prašume Čorkova uvala. *Šumarski list* XCVI(9 – 10): 325 – 333.
- Prpić B., Matić S., Vukelić J., Seletković Z., 2001: Bukovo-jelove prašume hrvatskih dinarida. Obična jela (*Abies alba* Mill.) u Hrvatskoj, s. 479
- Rozenbergar, D., Mikac, S., Anic, I. i Diaci, J. 2007. Gap Regeneration Patterns in Relationship to Light Heterogeneity in Two Old-Growth Beech Fir Forest Reserves in South East Europe. *Forestry* 80, 431-443.
- Runkle, J.R., 1982. Patterns of disturbance in some old-growth mesic forests of eastern North-America. *Ecology* 63, 1533–1546.
- Schliemann S.A. i Bockheim, J.G. 2011. Methods for Studying Treefall Gaps: A Review. *Forest Ecology Management*, 261, 1143–1151

- Stoker, J., Report of the First National Lidar Initiative Meeting, February 14-16, 2007, Reston, Va.
- Sumerling G., 2010: Lidar Analysis in ArcGIS 9.3.1 for Forestry Applications, An Esri White Paper, 2str.
- Tabaku, K.; Meyer, P., 1999: Lückenmuster albanischer und mitteleuropäischer Buchenwälder unterschiedlicher Nutzungsintensität. *Forstarchiv* 70: 87–97
- Thomas A. Nagel, Stjepan Mikac, Mojca Dolinar, Matija Klopčič, Srdjan Keren, Miroslav Svoboda, Jurij Diaci, Andrej Boncina, Vinko Paulić: The natural disturbance regime in forests of the Dinaric Mountains: A synthesis of evidence, *Forest Ecology and Management*
- Watt, A.S. (1947) Pattern and process in the plant community. *J. Ecol.* 35: 1-22.
- Whitmore, T.C., 1989. Canopy gaps and the two major groups of forest trees. *Ecology* 70, 536–538.
- Woodget A. S., D. Donoghue, P. Carbonneau, 2007: An assessment of airborne lidar for forest growth studies, *Ekscentar*, 10: 47–52.
- Woods, K.D., 2004. Intermediate disturbance in a late-successional hemlock-northern hardwood forest. *J. Ecol.* 92, 464–476.
- Yu, X., 2007: Methods and techniques for forest change detection and growth estimation using airborne laser scanning data, *Disertacija*, Helsinki University of Technology, 55 str.
- Zeibig, A., Diaci, J. i Wagner, S. 2005. Gap Disturbance Patterns of a *Fagus sylvatica* Virgin Forest Remnant in the Mountain Vegetation Belt of Slovenia. *Forestry Science and Landscape Research*, 79(1), 2.
- Zhao, K., S. Popescu, R. Nelson, 2009: LiDAR remote sensing of forest biomass: A scale-invariant estimation approach using airborne lasers, *Remote Sensing of Environment* 113 (1): 182–196.
- Žmegač, A., 2015 Upotreba laserskog skenera (LiDAR) u istraživanju dinamike bukovo-jelove prašume Čorkova uvala- Čudinka